

NADZOR U POMORSKIM SUSTAVIMA PRIMJENOM VREMENSKO-FREKVENCIJSKIH POSTUPAKA

Time-Frequency Methods in Maritime Surveillance Systems

dr. sc. Igor Vujović, dipl. ing.

Pomorski fakultet u Splitu

Sveučilište u Splitu

E-mail: ivujovic@pfst.hr

dr. sc. Joško Šoda, dipl. ing.

Fakultet elektrotehnike, strojarstva i brodogradnje

Sveučilište u Splitu

E-mail: jsoda@fesb.hr

prof. dr. sc. Slobodan M. Beroš, dipl. ing.

Fakultet elektrotehnike, strojarstva i brodogradnje

Sveučilište u Splitu

E-mail: sberos@fesb.hr

UDK 656.615:621.39

621.39:004.03

Sažetak

Pomorski sustavi za nadzor, u uvjetima povećane prijetnje globalnog terorizma, od primarne su važnosti za sigurnost prijevoza putnika, robe i usluga. Razvoj algoritma i izbor metode primjene za obradu signala imaju iznimnu ulogu pri projektiranju i učinkovitosti sigurnosnih sustava. U članku je predloženo istraživanje uporabe valične transformacije prilagođene za razlaganje slikovnih signala dobivenih iz videosustava uz pomoć analogne ili digitalne kamere, koja još nisu našla široku primjenu, kako bi se predstavila i ispravnim odabirom uporabila za točno određene svrhe. Na primjeru nadzora luke predstavljeni su i komentirani novi napredni algoritmi, kao što su pojasići, kontirući i krivuljići, obrade slikovnih signala uporabom valića, što su se pokazali izrazito djelotvorni i pri izdvajanju svojstava. U zaključku su komentirani rezultati istraživanja i potiče se diskusija o izboru metode.

Ključne riječi: lučki nadzorni sustavi, obrada signala, valična transformacija.

Summary

Maritime surveillance systems are crucial for port passenger, goods and services security under the circumstances of imminent threat from global terrorism. Algorithm development and proper decision-making on the appropriate signal processing method are vital for research and development of maritime surveillance systems. This paper researches how novel wavelet algorithms can be applied in real time image signal processing for port surveillance systems, in order to improve decision making and to improve global security of the ports. The emphasis of the paper is to choose the appropriate algorithm for the analysis, using real time port surveillance images and new wavelet based algorithms such as bandlets, contourlet and curvelets. In the paper conclusion, comments on obtained results are given and discussed.

Keywords: *harbour surveillance systems, signal processing, wavelet transformation*

UVOD / Introduction

Republika Hrvatska kao zemlja s velikom tradicijom u pomorskom prometu, lučkom prometu, brodogradnji i ostalim djelatnostima vezanim za pomorstvo, zbog pomorske tradicije i u uvjetima globalne prijetnje terorizmom, razvija sustave za upravljanje i nadziranje lučkog prometa, roba i usluga, te sustave za rano dojavljivanje, uzbunjivanje i spašavanje unesrećenih na moru. Kvaliteta i učinkovitost tih sustava ogleda se u razvoju i uporabi posebno prilagođenih algoritama za obradu signala. Algoritmi se za obradu signala rabe u pomorstvu, u mnogim primjenama, poput radara, GPS-a, elektroničkih kartata, autopilota, alarmnih sustava, sustava automatske regulacije (autonomnih podvodnih ili površinskih plovila) [12] i drugom. Signali sadržavaju informacije u vremenskoj, frekvencijskoj i/ili prostornoj domeni. Klasičnim pristupom razlaganju promatranog signala, to jest informacije iz signala, on se transformira iz izvorne u drugu prigodnu domenu. Valja istaći da su promatrani signali izrazito nestacionarnog karaktera, te s klasičnim tehnikama analize signala, kao primjerice uporabom njegova spektra uz pomoć Fourierove transformacije (FT), ne mogu se dobiti odgovori na sve postavljene ciljeve istraživanja i relevantni zaključci. Temeljni se nedostatak pritom očituje u tome što algoritam Fourierove transformacije odbacuje vremensku domenu, a često je cilj tijekom istraživanja otkriti određene pojave u nekome vremenskom slijedu, a Fourierovom analizom to nije moguće. Zato se razvijaju novi, napredniji pristupi i rabe se transformacije tako da se promatrani signal prebaci iz jednoga u drugi vektorski prostor (višedimenzionalni prostor), gdje se izdvajaju karakteristična svojstva iz signala, pa se na taj način donose relevantni zaključci istraživanja. Jedna od tehnika razlaganja signala koje se danas razvijaju jest uporaba vremensko-frekvencijske analize, gdje se izdvajaju tehnike analize signala temeljene na valičnoj transformaciji [7, 22]. Razvojem višeprocorskih računala i tehnologije, jedan od signala za razlaganje i analizu je videosignal koji se preuzima iz analogne ili digitalne kamere ili više njih istodobno u stvarnom vremenu. Primjerice, radarska slika ili radarski odraz je promatrani signal, pa se različitim tehnikama analize iz radarskog odraza može izlučiti naftna mrlja na moru, kao svojstvo [1, 2]. Valja istaći da je poseban izazov u generiranju i izvođenju algoritama u ograničenom vremenu to što ono mora zadovoljavati određene norme kao, primjerice, biti manje od tromosti ljudskog oka.

Nadzorni se sustavi mogu rabiti u različitim namjenama, od VTS-a do nadzora paluba. Ideja kako tehnološki unaprijediti hrvatsku brodogradnju temelji se na unošenju dodatne vrijednosti u konačni proizvod [23, 24], pa jedna od njih može biti i razvijanje sigurnosnog sustava

poput videonadzora paluba u putničkom brodu, zatim prodavaonica, kockarnica, bazena i drugih oblika zabave za putnike, tijekom izgradnje broda. Korist od uvođenja videonadzora ogleda se u prevenciji pljački i prijevara i u identificiranju počinitelja [5, 15, 25]. Videosustavi temeljeni na uporabi strojnog vida mogu se razviti i uporabiti u nadzoru strojeva [14] i u telemedicinskim primjenama [10, 19, 20], zatim u nadzoru luka i lučkih zaljeva te dokova [21, 26]. Očita njihova prednost je u 24-satnom nadzoru prostora i sprječavanja ilegalnih aktivnosti svih vrsta.

Sustavi videonadzora dostupni su na tržištu [4, 6, 13], ali imaju još uvijek neriješenih poteškoća u stvarnoj primjeni, poput vibracija zbog brodskog motora [14] ili varijacija osvjetljenosti [27]. Da bi se udovoljilo novim tehnologijama i razvijale poboljšane inačice postojećih proizvoda, potrebno je biti u tijeku s trendovima u području obrade i analize signala. U nove trendove ubraja se valična transformacija, ali i one temeljene na uporabi valića u različitim vektorskim područjima i domenama. Ovaj članak donosi istraživanje autora odabira prigodnih algoritama i njihove primjene u aplikacijama za videonadzor s naglaskom na pomorstvu.

U drugom poglavlju članka predstavljeni su temelji vremensko-frekvencijskih transformacija i temeljni problem razlučivosti signala, pa Fourierova i valična transformacija, uz temeljna svojstva i karakteristike. U trećem poglavlju izložene su nove transformacije pogodne za obradu slikovnih signala. Istražuju se temeljna svojstva i donosi se kritički osvrt na valičnu transformaciju. U četvrtom poglavlju na primjeru obrade slikovnog signala pri nadzoru luke i lučkog prometa, predstavljeni su algoritmi obrađeni u prethodnim poglavljima. Na kraju su doneseni zaključci.

OBRADA SIGNALA I HEISENBERGOVO NAČELO NEODREĐENOSTI / *Signal processing and heisenberg uncertainty principle*

Heisenbergovo načelo neodređenosti [11] fundamentalni je zakon u obradi signala. Doslovni prijevod tog načela glasi: „Ne mogu se savršenom preciznošću znati oba značajna čimbenika koja određuju kretanje jedne čestice – položaj i brzina. Nemoguće je precizno odrediti poziciju i brzinu čestice istovremeno.“ Pravilo je formulirano izrazom:



$$\Delta x \cdot \Delta p \geq \hbar \quad (1)$$

U kontekstu obrade signala, a osobito vremensko-frekvencijske analize, načelo neodređenosti naziva se i Gaborovim ograničenjem [9] i opisano je izrazom:

$$\Delta \omega \cdot \Delta t \geq \hbar \quad (2)$$

Ovo načelo pokazuje da je površina prozora vremensko-frekvencijske ravnine, u kojemu se amplituda može smatrati konstantnom, ograničena najmanjom fizikalno mogućom veličinom iznosa \hbar , to jest da je omeđena s donje strane. Ako se želi izlučiti točan podatak o frekvenciji, tada će podatak o vremenu biti beskonačno pogrešan. Želi li se dobiti podatak o vremenu, tada će podatak o njegovoj frekvenciji biti beskonačno pogrešan (slika 1.). U praksi se ne mogu odrediti ni frekvencija ni vrijeme beskonačno točno, nego u određenome malenom intervalu. Jednadžba (2) rezultat je Benedicksova poučka, koji glasi:

Poučak 2.1. Za skup točaka kod kojih je f različito od nule i skup točaka kod kojih je \hat{f} različito od nule, vrijedni da oba ne mogu biti mala. Nemoguće je za funkciju f iz $L^2(\mathbf{R})$ i njezinu Fourierovu transformaciju da obje imaju domenu na skupu konačnih Lebesgueovih mjera.



Slika 1. Vremensko-frekvencijski paradoks: a) vremena, b) frekvencije
Figure 1 Time-frequency paradox of: a) time, b) frequency

Transformacija koja je pokrenula razvoj i istraživanja u području telekomunikacija i automatike je kontinuirana Fourierova transformacija (FT), što se (transformacija i inverzna transformacija) opisuje jednadžbama:

$$x(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} X(j\omega) \cdot e^{j\omega t} d\omega, \quad X(j\omega) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j\omega t} dt = \langle x(t), e^{j\omega t} \rangle \quad (3)$$

FT transformacija je pogodna za analizu stacionarnih signala. Da bi se proširila uporaba transformacije za rješavanje nestacionarnih signala, ona se modificira tako da se računa linijski spektar za određeni vremenski interval, uvođenjem prozorske funkcije. Opisana se modifikacija naziva *prozorska Fourierova transformacija* (STFT) ili FT u kratkome vremenskom intervalu i opisuje se izrazom:

$$STFT_x^\omega(\tau, \omega) = \int_t [x(t) \cdot W(t - \tau)] \cdot e^{-j\omega t} dt \quad (4)$$

gdje je parameter vremena τ , parameter frekvencije ω , signal koji treba analizirati $x(t)$, W prozorska funkcija, $t - \tau$ je parametar posmaka prozora u $t = \tau$. Eksponencijalna funkcija, $e^{-j\omega t}$ predstavlja FT kernel ili baznu funkciju (engl. *basis function*) u Fourierovoj transformaciji, dok $STFT_x^\omega(\tau, \omega)$ označava koeficijent koji se dobiva kao rezultat, a računa se za svaku vrijednost posmaka (lokalizirani spektar) na određenoj frekvenciji ω .

Valja razlikovati dva ekstremna slučaja pri uporabi STFT algoritma: kada je $W(t)$ beskonačno dugo, tj. $W(t) = 1$, i kada je $W(t)$ beskonačno kratko, tj. $W(t) = \delta(t)$. U prvom se STFT transformacija pretvara u klasičnu FT transformaciju. U drugom STFT transformacija daje vremenski signal s pomakom u fazi, gdje se dobiva izvrsna vremenska, ali ne i frekvencijska rezolucija. Može se izvesti zaključak da prozor velike širine za analizu znači slabu vremensku, a dobru frekvencijsku razlučivost. Uzak prozor za analizu znači dobru vremensku, a lošu frekvencijsku razlučivost. Valja istaknuti da jednom kad je širina prozora odabrana, rezolucija je postavljena i ne mijenja se tijekom primjene algoritma.

Kod valića kernel je prototipna funkcija, i naziva se *osnovni valić* (engl. *mother wavelet*), i opisana je izrazom:


$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (5)$$

gdje je a parametar skale, $\frac{1}{\sqrt{a}}$ je parametar normalizacije koji omogućuje da svi valići imaju istu energiju, a parametar skale i b parametar translacije. Algoritam se valićne transformacije definira izrazom:


$$CWT_x^{(\psi)}(a,b) = W(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} x(t) \cdot \psi^* \left(\frac{t-b}{a} \right) dt \quad (6)$$

gdje je CWT koeficijent koji se dobiva za određenu skalu a i posmak b i ψ^* osnovni valić s posmakom b i skaliran je za a . Izraz (6) naziva se kontinuirana valićna transformacija. I Fourierova i valićna transformacija imaju i izravnu inačicu kako bi se mogle implementirati na računalu. Također se ovisno o primjeni mogu definirati i u više dimenzija.


Slika 2. prikazuje podjelu vremensko-frekvencijske ravnine za FT , $STFT$ i valićnu transformaciju. Kao što je prikazano na slici 2.a), kod FT transformacije dobiva se idealna frekvencijska razlučivost, pa je moguće odrediti frekvenciju, ali ne i vremenski interval u kojemu dotična frekvencijska komponenta egzistira. Na slici 2.b) prikazana je vremensko-frekvencijska ravnina kod $STFT$ transformacije, gdje se vidi da su prozori jednaki za frekvenciju i vrijeme za visoko i niskofrekvencijske komponente. Jednom kada se širina prozora odredi, ostaje konstantnom tijekom izvršavanja algoritma. $STFT$ transformacija posebice se učinkovitom pokazala u obradi akustičkih signala.



a)



b)



c)

Slika 2. Veličina prozora u vremensko-frekvencijskoj ravnini za: a) FT , b) $STFT$, c) valiće

Figure 2 Windows' size (tilling) in the time-frequency plane for: a) FT , b) $STFT$, c) wavelets

Na slici 2.c) prikazana je vremensko-frekvencijska ravnina kod valićne transformacije. Uočava se da na visokim frekvencijama ima bolju vremensku razlučivost, što je karakterizirano pravokutnicima uske baze u vremenskom, a široke baze u frekvencijskom području, dok na niskim frekvencijama ima bolju frekvencijsku razlučivost, što je karakterizirano širokom bazom u vremenskom, a uskom u frekvencijskom području. Valja istaknuti da, iako je širina prozora promjenjiva tijekom izvršavanja algoritma, površina je vremensko-frekvencijskog prozora u svakom trenutku konstantna i određena je Heisenbergovim poučkom. Teorija valića počiva na pojmovima posmaka i skale. Posmak je izravno koreliran s vremenskom osi, dok je parametar skale izravno koreliran s frekvencijskom osi. Također, tijekom uporabe, valićna transformacija može imati različite fizičke interpretacije.

U analizi slikovnih podataka značajne fizičke veličine koje se proučavaju jesu: boja, broj piksela određene boje i pozicija gdje se određena boja nalazi. Matematičkim rječnikom iskazano: fizičke se značajke slikovnih signala prikazuju u četverodimenzionalnome vektorskom prostoru. Dvodimenzionalna obradba signala sadržava posebne geometrijske i topološke probleme kojih nema u jednodimenzionalnoj. Tako, primjerice, kauzalnost nije dobro definirana u dvije dimenzije. Da bi se zaobišli problemi povezani sa složenošću unesene drugom dimenzijom, odnosno rješavanje problema u višedimenzionalnim vektorskim prostorima, upotrebljuje se sljedeće razmišljanje: proširuje se jednodimenzionalni alogaritam na dvodimenzionalni uvođenjem odvojenog pristupa (engl. *separable approach*), gdje se rabi teorija tenzora i njihovi poučci [16].

Poučak o umnošku tenzora služi da bi se proširio umnožak jednodimenzionalnih signala u umnožak višedimenzionalnog signala. Oznaka za tenzorski umnožak je \otimes . Tenzorski umnožak $f_1 \otimes f_2$ između vektora u dva Hilbertova prostora, H_1 i H_2 zadovoljava svojstva linearnosti i distributivnosti, pa se opisuje izrazima:

$$\lambda(f_1 \otimes f_2) = (\lambda f_1) \otimes f_2 = f_1 \otimes (\lambda f_2) \quad (7)$$

$$(f_1 + g_1) \otimes (f_2 + g_2) = (f_1 \otimes f_2) + (f_1 \otimes g_2) + (g_1 \otimes f_2) + (g_1 \otimes g_2) \quad (8)$$

Tenzorski umnožak stvara novi Hilbertov prostor $H = H_1 \otimes H_2$ koji uključuje sve vektore oblika $f_1 \otimes f_2$, gdje je $f_1 \in H_1$ i $f_2 \in H_2$, kao i ostale linearne kombinacije tih vektora. Poučak o produktu skalarnih veličina u H prostoru izveden je iz umnoška skalara H_1 i H_2 . Sljedeći poučak pruža mogućnost jednostavne pretvorbe baze za jednodimenzionalni signal u odvojive baze za višedimenzionalne signale [16].

Poučak 2.2. Neka je $H = H_1 \otimes H_2$. Ako su $\{e_n^1\}_{n \in N}$ i $\{e_n^2\}_{n \in N}$ Rieszove baze na H_1 i H_2 vektorskim prostorima, tada je $\{e_n^1 \otimes e_m^2\}_{n,m \in N^2}$ Rieszova baza u H vektorskom prostoru. Ako su te dvije baze ortonormalne, tada je i tenzorski umnožak baznih vektora također ortonormalan.

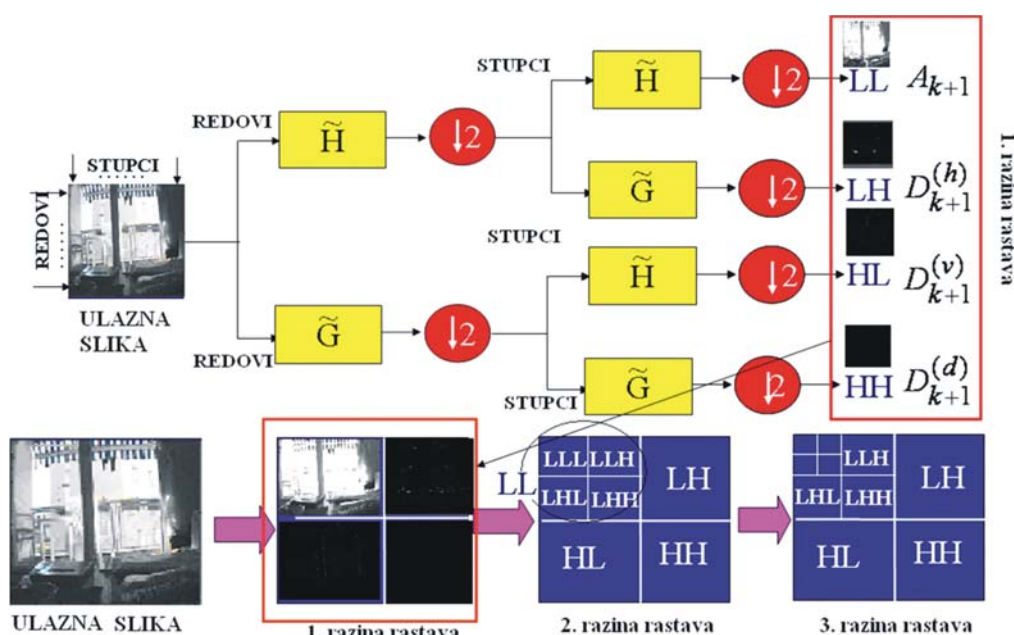
Poučak 2.2. omogućuje rješavanje problema implementacije višedimenzionalne valične transformacije, a time se može izravno primijeniti pri obradi slikovnih signala.

Slika 3. prikazuje ideju razlaganja slikovnog signala uz uporabu valične transformacije. Na ulazni se slikovni signal aplicira filtarski slog (engl. *filter bank*) koji se

sastoji od niskopropusnog (\tilde{H}) filtra, koji propušta donju polovicu frekvencijskog spektra signala, i visokopropusnog (\tilde{G}) filtra, koji propušta gornju polovicu frekvencijskog spektra signala po recima. Na dobivene uzorke nakon apliciranja filtarskog sloga primjenjuje se operacija poduzorkovanja ($\downarrow 2$), gdje se svaki drugi uzorak iz dobivenih uzoraka, zbog redundantnosti odbacuje, pa se kao rezultat dobiva upola manje uzoraka od redaka slikovnog signala. Zatim se opisana operacija ponavlja po stupcima, i dobiva se upola manje uzorka od stupaca slikovnog signala. Rezultat dvostrukog apliciranja niskopropusnog filtra je signal aproksimacija (LL), koji sadržava više od 90% ukupne energije slikovnog signala. Apliciranjem slikovnog signala kroz ostale kombinacije filtara dobivaju se koeficijenti detalja valične transformacije i oni se označavaju kao: vodoravni (LH), okomiti (HL) i dijagonalni (HH) koeficijenti.

TRANSFORMACIJE INSPIRIRANE VALIĆIMA / Wavelet inspired transforms

Uporaba valića u raznovrsnim aplikacijama rezultira golemim napretkom i uspjesima i pri primjenama u jednodimenzionalnim signalima i u onima kod višedimenzionalnih signala. Osobito značajan uspjeh postignut je u sažimanju slikovnih signala, primjerice u generiranju baze otisaka prstiju u FBI agenciji. U današnje vrijeme, valići se rabe za obradu i analizu višedimenzionalnih signala, poput obrade i analize slikovnih signala, pa se razvijaju nove transformacije



Slika 3. Valična analiza slike
Figure 3 Wavelet analysis of an image

temeljene na valićima a najčešće su dobile ime prema namjeni u primjeni u slikovnim signalima. Valja istaknuti da je većina novih transformacija što se temelje na valićima razvijena na temeljima promjene koordinatnog sustava u vektorskom prostoru, te na uvođenju novih baznih vektora. Ako se zarotira osnovna baza valića, dobivaju se valići nazvani *pojasići* (engl. *bandelet*). Njihova je temeljna karakteristika da su ortonormalni, i prilagođeni su geometrijskim granicama u slici [17]. Pojasići se rabe za transformaciju glatkih funkcija s glatkim granicama područja. Da bi se bolje transformirali različiti oblici objekata u slikovnim signalima, razvijaju se i valići nazvani *konturići* (engl. *contourlets*) i *krivuljići* (engl. *curvelets*); oni se također konstruiraju iz temeljnih valića [18]. Sljedeće dvije definicije definiraju pojasiće i krivuljiće.

Definicija 3.1. Definiranje skupa koeficijenata pojasićne transformacije izvodi se pretvorbom koeficijenata temeljnih valića u pojasićne uporabom tzv. Alpertove transformacije, ako i samo ako je vektor koji odgovara uzorkovanju anizotropne funkcije dobro aproksimiran s nekolicinom vektora iz tzv. Alpertova skupa baznih funkcija. Naznačeni koeficijenti mogu biti zapisani kao skalarni produkt $\langle f, b_{j,\ell,n}^k \rangle$ izvornoga slikovnog signala f s pojasićnom funkcijom koja je linearna kombinacija valićne funkcije:

$$b_{j,\ell,n}^k(x) = \sum_p a_{\ell,n}[p] \psi_{j,p}^k(x) \quad (9)$$

gdje je $a_{\ell,n}[p]$ koeficijent tzv. Alpertove transformacije.


Definicija 3.2. [3] Neka je $x = (x_1, x_2)$ slučajna varijabla. Krivuljić je definiran na skali 2^j orijentacijom θ_l i položajem $x_k^{(j,l)} = R_{\theta_l}^{-1}(k_1 \cdot 2^{-j}, k_2 \cdot 2^{-j/2})$ izrazom:

$$\varphi_{j,k,l}(x) = \varphi_j(R_{\theta_l}(x - x_k^{(j,l)})) \quad (10)$$

gdje je R_θ rotacija za θ radijana a matematički odgovara

$$\text{Givensovoj rotaciji } R_\theta = \begin{bmatrix} \cos \theta & \sin \theta \\ -\sin \theta & \cos \theta \end{bmatrix}.$$

Najznačajnija svojstva krivuljića su: parabolično skaliranje, osilacijsko ponašanje, momenti nestajanja i uski prozori. Uz spomenute transformacije postoji još čitav spektar onih koje se temelje na valićima a dobile su ime prema primjenama, kao primjerice: *rubići* (engl. *edgelets*), koji su izrazito povoljnih karakteristika u otkrivanju rubova objekata/područja u slikovnom signalu, *oblikići* (engl. *shapelets*), koji se konstruiraju prema proizvoljnim oblicima [8] i ostali.



Slika 4. Podjela prostorno-frekvencijske domene kod krivuljića


Figure 4 Curvelet tiling [3]

PRIMJENA NAPREDNIH ALGORITAMA ZA OBRADU SLIKOVNIH SIGNALA TEMELJENIH NA UPORABI VALIĆNE TRANSFORMACIJE U NADZORU POMORSKE LUKE / Advanced time-frequency algorithms in image processing for port surveillance applications


Istraživanja problema usporedbe različitih transformacija temeljenih na valićima, proizlazi iz nestandardnosti programskih rješenja koja su javno dostupna. Dok su se za valiće i Fourierovu transformaciju razvili komercijalni programski alati, za ostale spomenute transformacije i algoritme to nije tako. Slika 5. izvorna je slika (brodovi na suhom doku) na koju će se aplicirati brzi algoritam valićne transformacije te algoritmi pojasićne, konturićne i krivuljićne transformacije. Slika 6.a prikazuje razlaganje slikovnog signala, slike 5., uporabom brzog algoritma valićne transformacije, na koeficijente aproksimacije koji su predočeni u lijevom gornjem dijelu slike slike 6.a, te također na koeficijente detalja predstavljene vodoravnim koeficijentima detalja (gornji desni dio slike 6.a), okomitim koeficijentima detalja (donji lijevi dio slike 6.a) i tzv. dijagonalnim koeficijentima detaljima (donji desni dio slike 6.a).




Slika 5. Izvorna slika
Figure 5 Original image



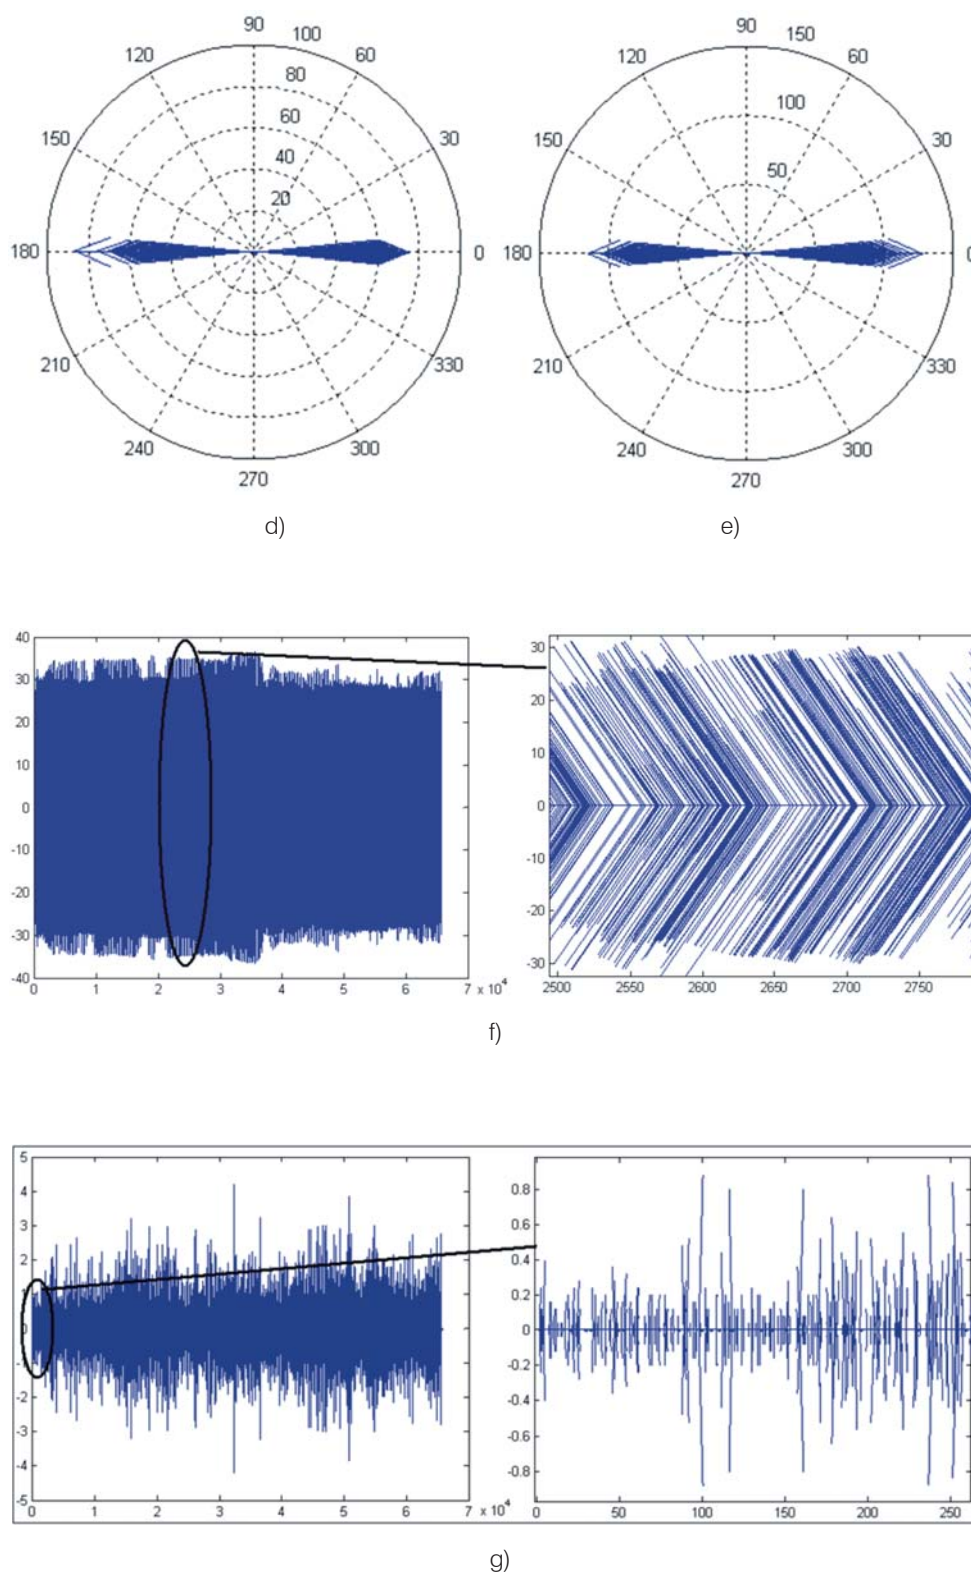
a)



b)



c)

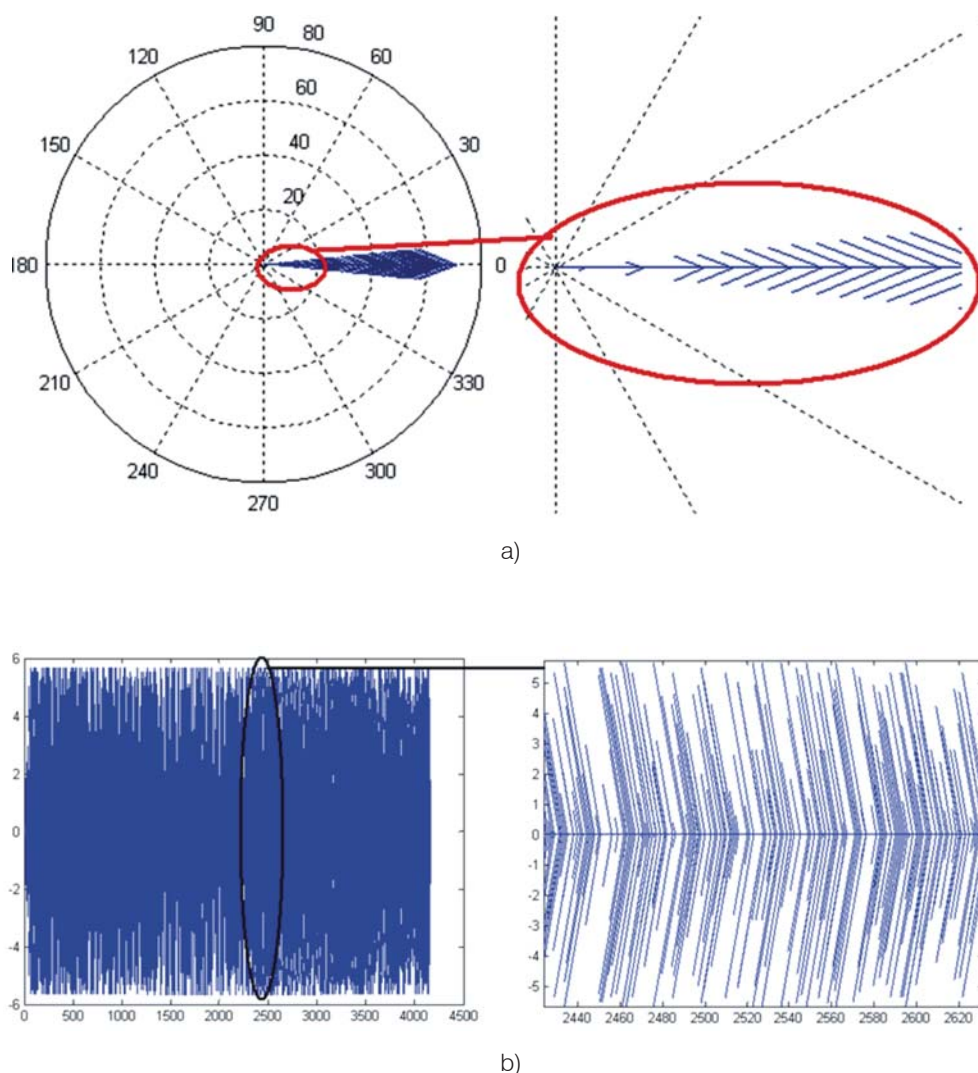


Slika 6. a) Razlaganje izvorne slike uporabom brzog algoritma valične transformacije, b) kompasni graf aproksimacije, c) kompasni graf dijagonalnih detalja, d) kompasni graf vodoravnih detalja, e) kompasni graf okomitih detalja, f) graf vektora brzine aproksimacije, g) graf vektora aprkoksimacije dijagonalnih detalja.

Figure 6 a) Wavelet decomposition of the original image, b) compass graph of the approximation, c) compass graph of the diagonal details, d) compass graph of the horizontal details, e) compass graph of the vertical details, f) velocity vector graph of the approximation, g) velocity graph of the diagonals details


Slike 6. b, c, d i e prikazuju usmjerenost koeficijenata u tzv. kompasnom grafu. S desne su strane uvećani dijelovi slike s lijeve strane. Vidi se da je aproksimacija usmjerena u jednu stranu, dok su detalji usmjereni u dvije strane različitim intenzitetom, što pokazuje da je konstrukcija broda pod kutom prema osi kamere. Vektori su brzina na slikama 6.f i g. Slika 7. prikazuje kompasni graf i graf brzine za proračunatu geometriju pri proračunu pojasića. Desni dio slike 8.a uvećani je najmanji dio piramide lijeve slike. Takav prikaz nije moguće usporediti s npr. valićnim jer program ne omogućuje isti način proračuna i prikaza slika. Na slici

9. su koeficijenti uz upotrebu algoritma tzv. krivuljne transformacije. Vidi se da energija krivuljnih koeficijenata nije koncentrirana u koeficijentima aproksimacija kao kod valićne transformacije ili uporabom transformacije temeljene na konturicama, jer su svi koeficijenti dominantno tamni. Umjesto vodoravnih, okomitih i dijagonalnih detalja, ovdje su detalji pod određenim kutovima, što npr. pri snimanju morske površine može značiti da će se u određenim koeficijentima vidjeti odsjaj valova, a pod određenim kutovima neće. To svojstvo pomaže u isključivanju lažnih kretnja iz slike pri nadzoru luka.




Slika 7. a) Kompasni graf izračunate geometrije za pojasiće, b) graf vektora brzine u izračunatoj geometriji pojasića.

Figure 7 a) Compass graph of the bandlets' computed geometry, b) velocity graph of the computed geometry for bandlets




a)



b)

Slika 8. a) Razlaganje izvorne slike konturičnom transformacijom, b) kompasni graf koeficijenata aproksimacije konturića.

Figure 8 a) Contourlet decomposition of the source image, b) compass graph of the contourlet approximation coefficients



Slika 9. Koeficijenti krivuljića

Figure 9 Curvelet coefficients

ZAKLJUČAK / Conclusion

Valja istaknuti da je u prikazanim istraživanjima uporabe brzih algoritama temeljenih na valićima u različitim domenama, pri obradi slikovnih signala za nadzor pomorskih sustava, odabir pogodnog algoritma od velike važnosti, a ovisi o prirodi problema i svrsi primjene. Pokazalo se da u pojedinim primjenama nije dostatno samo primijeniti novorazvijeni algoritam jer se događalo da se odabirom algoritma znatno smanjila učinkovitost aplikacije, pa je primjena izgubila svrhu. Značajni problemi što su se pojavili „krivim“ odabirom algoritma jest nemogućnost obrade slikovnog podatka u stvarnom vremenu zbog vremena potrebnoga za računanje i obradu koeficijenata tijekom razlaganja signala. Time je svrhovitost aplikacije postala upitnom, uz netočno izdvajanje i interpretaciju svojstava, kao primjerice pojava istovjetnih objekata u slici kao posljedica jednog objekta - tzv. „duhovi“, zatim pojava objekata u slici kojih uopće nema u izvornoj slici i slično. Iako su se predstavljene transformacije pokazale kao poboljšanja u pojedinim područjima primjene, autori članka naglašavaju potrebu za nastavak istraživanja na predloženom problemu, a posebice se to odnosi na uporabu u pomorskim nadzornim sustavima, jer je tu više potencijalnih problema koje treba riješiti da bi predložene transformacije bile uporabljene u stvarnim sustavima.

Uz to što je u članku dan pregled stanja u ovom području znanosti, valja istaknuti i doprinos u definiranju terminologije i prijevodu novih termina i izraza na hrvatski jezik. Problem nedefiniranosti i usklađenosti terminologije proizlazi iz činjenice što je ovo područje obrade signala relativno mlado i brzo se razvija, kao što je to i u svim novim znanstvenim područjima. Autori članka uvode i predlažu terminologiju, te pozivaju sve znanstvenike i stručnjake iz ovoga područja da se uskladi terminologija i prijevodi u duhu tehničkoga hrvatskog jezika.

LITERATURA / References

- [1] Akkartal, A., Sunar, F., The Usage of Radar Images in Oil Spill Detection, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. 37, 2008, pp. 271-277.
- [2] Brekke, C., Solberg, A., *Feature Extraction for Oil Spill Detection Based on SAR Images*, Lecture notes in computer science, vol. 3540/2005, Springer, Berlin, pp. 75-84. 2005.
- [3] Candés, E., Demanet, L., Donoho, D., Ying, L., Fast Discrete Curvelet Transforms, *Multiscale Modeling and Simulation*, 2006, 5(3), pp. 861-899.
- [4] CCTV gadgets, on-line: <http://www.cctvgadgets.com>
- [5] Choi, S. I., Choi, C. H., Kwak, N., Face Recognition Based on 2D Images Under Illumination and Pose Variations, *Pattern Recognition Letters*, 32 (2011), pp. 561-571.
- [6] Cyberia Corporation, on-line: <http://www.cyberia-company.fr>
- [7] Daubechies, I., *Ten Lectures on Wavelets*, Society for Industrial and Applied Mathematics, Philadelphia, 1992.
- [8] Donoho, D., Huo, X., Edgelets & Wedgelets Software & Applications, on line: http://www.waveletidr.org/workshop2/posters/xiaoming_huo3.pdf
- [9] Gabor, D., Theory of communication, Journal of the Institute of Electrical Engineers, 1946, 93(26), pp. 429-457.
- [10] Greenauer, M., Navy telemedicine initiative, *Proceedings of the National Forum Military Telemedicine On-Line Today*, 1995. 'Research, Practice, and Opportunities', McLean, VA, USA, 27-29 March 1995, pp. 77-79.
- [11] Heisenberg, W., Über den anschaulichen Inhalt der quantentheoretischen Kinematik und Mechanik, *Zeitschrift für Physik*, 1927, 43 (3-4), pp. 172-198, doi:10.1007/BF01397280
- [12] Huntsberger, T., Aghazarian, H., Howard, A., Trotz, D.C., Stereo Vision-Based Navigation for Autonomous Surface Vessels, *Journal of Field Robotics*, 2011, 28(1), pp.3-18.
- [13] Imaging Corporation, on-line: <http://www.imaging1.com>
- [14] Kuzmanić, I., Šoda, J., Antonić, R., Vujović, I., Beroš, S., Monitoring of oil leakage from a ship propulsion system using IR camera and wavelet analysis for prevention of health and ecology risks and engine faults, *Material. u. Werkstoff.*, 2009, 40(3), pp.178-186.
- [15] Liu, C. C., Dai, D. Q., Face Recognition Using Dual-Tree Complex Wavelet Features, *IEEE Transactions on Image Processing*, 2009, 18(11), pp. 2593-2599.
- [16] Mallat, S., *A Wavelet Tour of Signal Processing*, New York, Academic Press, 1999.
- [17] Pennec E., Mallat, S., Sparse Geometric Image Representations With Bandelets, *IEEE Transactions on Image Processing*, 2005, 14(4), pp. 423-438.
- [18] Peyre, G., Pennec, E., Dossal, C., Geometric estimation with orthogonal bandlet bases, *Proceedings SPIE Wavelets XII*, San Diego, August 26-29, 2007, pp. 67010M.1-67010M.10.

- [19] Reed, C., Burr, R., Melcer, T., Navy Telemedicine: A Review of Current and Emerging Research Models, *Telemedicine Journal and e-Health*, 2004, 10(3), pp. 343-356.
- [20] Sadiq, M. A., Juzoji, H., Nakajima, I., Igarashi, K., Tanaka, K., Validating the role of Mobile Telemedicine Package in Marine Time Teleconsultations, on-line: <http://libir.tmu.edu.tw/bitstream/987654321/21563/1/P07.pdf>
- [21] Smookler, M. S., Clark, B. G., Ostrander, J. M., Underwater detection and surveillance technology for commercial port and vessel security. Who is going to pay for it?, *Proceedings of MTS/IEEE Oceans*, 2005, vol. 1, pp. 935-940.
- [22] Sweldens, W., The Lifting scheme: a construction of second generation wavelets, *SIAM Journal on Mathematical Analysis*, 1997, 29(2), pp. 511-546.
- [23] Šerić, N., Rebranding Croatian Shipbuilding to Global Market, *12th Paneuropean Shipping Conference*, 24-25 November 2011, Split, Croatia
- [24] Šoda, J., Vujović, I., Beroš, S. M., Kuzmanić, I., Harbor and Shipyard Surveillance - Wavelet Pairs in Suppression of Illumination Variations, *12th Paneuropean Shipping Conference*, 24- 25 November 2011, Split, Croatia
- [25] Zhang, T., Tang, Y. Y., Fang, B., Shang, Z., Liu, X., Face Recognition Under Varying Illumination Using Gradientfaces, *IEEE Tran. Image Proc.*, 2009, 18(11), pp. 2599-2606.
- [26] Tao, R., Feng, Y., Wang, Y., Theoretical and experimental study of a signal feature extraction algorithm for measuring propeller acceleration in a port surveillance system, *IET Radar Sonar Navig.*, 20011, 5(2), pp. 172-181.
- [27] Vujović, I., Kuzmanić, I., Beroš, S. M., Šoda, J., Choosing Wavelet Pairs in Suppression of Illumination Variations for Port Surveillance, *Proceedings of ELMAR*, 14-16 September 2011, Zadar, Croatia, pp. 75 – 78.

Rukopis primljen: 13. 1. 2012.

